



UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
CURSO DE GRADUAÇÃO EM ENGENHARIA DA COMPUTAÇÃO

Otávio Belfort Silva

**Análise de sentimento: principais conceitos e
aplicação**

São Luís - MA

2022

Otávio Belfort Silva

Análise de sentimento: principais conceitos e aplicação

Monografia apresentada ao curso de Engenharia da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia da Computação.

Graduação em Engenharia da Computação

Universidade Federal do Maranhão

Orientador: Prof. Dr. Ivo José da Cunha Serra

São Luís - MA

2022

Otávio Belfort Silva

Análise de sentimento: principais conceitos e aplicação

Monografia apresentada ao curso de Engenharia da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia da Computação.

Trabalho aprovado em: São Luís - MA, 21 de Dezembro de 2022

Prof. Dr. Ivo José da Cunha Serra
Orientador
Universidade Federal do Maranhão

Prof. Dr. Davi Viana dos Santos
Examinador
Universidade Federal do Maranhão

Prof. Dr. Sérgio Souza Costa
Examinador
Universidade Federal do Maranhão

São Luís - MA
2022

Resumo

A análise de sentimento atua como instrumento que visa explorar informações que podem ser obtidas por meio de dados disponíveis principalmente em ambientes virtuais como em *e-commerce* e redes sociais, onde pessoas compartilham suas opiniões, experiências ou emoções sobre uma entidade qualquer (serviço, produto ou pessoa). Para isso, a análise de sentimento implementa técnicas, métodos e ferramentas que identificam o sentimento, as emoções ou opiniões das pessoas através da mineração de dados. Diante disso, este trabalho apresenta as bases conceituais, processos, etapas e níveis que compõem o campo de estudo da análise de sentimento, dando ênfase a um dos seus níveis, o nível de aspecto, que é baseado em recursos e permite a identificação de sentimentos implícitos por ter uma abordagem interpretativa. Também destaca-se sua relevância e apresenta algumas discussões com base em um experimento que busca identificar o aspecto do sentimento de pessoas em resenhas sobre livros.

Palavras-chave: Análise de sentimento, Nível de aspecto, Mineração, Resenha.

Abstract

Sentiment analysis acts as an instrument that aims to explore information that can be acquired through data available mainly in virtual environments such as *e-commerce* and social networks, where opinions, experiences or emotions about any entity have inspired people (service, product or person). For this, sentiment analysis implements techniques, methods and tools that identify people's feelings, emotions or opinions through data mining. Therefore, this work presents the conceptual bases, processes, steps and levels that make up the field of study of sentiment analysis, emphasizing one of its levels, the aspect level, which is based on resources and also capable of identifying feelings. implied by having an interpretive approach. It also highlights its relevance and presents some discussions based on an experiment that seeks to identify the aspect of people's feelings in book reviews.

Keywords: Sentiment analysis, Aspect level, Mining, Digest

Lista de ilustrações

Figura 1 – Etapas da análise de sentimento.	12
Figura 2 – Abordagem baseada em dicionário.	18
Figura 3 – Técnicas de classificação de sentimentos.	19
Figura 4 – Resultados do método FREQ Baseline com o <i>corpus</i> ReLi estendido.	30
Figura 5 – Resultados obtidos usando o método FREQ + <i>Word2Vec</i> com o <i>corpus</i> ReLi.	33
Figura 6 – Melhores resultados obtidos para os parâmetros precisão, revocação e medida f de cada metodo usando o <i>corpus</i> ReLi.	34
Figura 7 – Melhores resultados obtidos para os parâmetros precisão, revocação e medida f de cada metodo usando o <i>corpus</i> ReLi Estendido.	34

Lista de tabelas

Tabela 1 – Exemplo de abordagem supervisionada	14
Tabela 2 – Composição do <i>corpus</i> ReLi distribuída em função dos autores quantidades de resenhas, frases e palavras	25
Tabela 3 – Composição das frases em percentuais do <i>corpus</i> ReLi quanto a sua polaridade e presença de aspectos.	26
Tabela 4 – Composição da frases com a ocorrência ou não de aspectos no <i>corpus</i> ReLi.	26
Tabela 5 – Ocorrências de aspectos simples e compostos.	26
Tabela 6 – Métricas de avaliação da precisão e revocação	27
Tabela 7 – Percentuais da precisão, revocação e <i>medida f</i> obtidos com o método FREQ Baseline	29
Tabela 8 – Resultados obtidos usando o método Hu & Liu com <i>corpus</i> ReLi.	30
Tabela 9 – Resultados obtidos usando o método Hu & Liu com o <i>corpus</i> ReLi sem sintagmas.	31
Tabela 10 – Resultados obtidos usando o método FREQ + <i>Word2Vec</i> com o <i>corpus</i> ReLi.	32
Tabela 11 – Resultados obtidos usando o método FREQ + <i>Word2Vec</i> com o <i>corpus</i> ReLi estendido.	33

Lista de abreviaturas e siglas

API	<i>Application Programming Interface</i>
SVM	<i>Support Vector Machines</i>
IDE	<i>Integrated Development Environment</i>
PUC	<i>Pontifícia Universidade Católica</i>
NLPNET	<i>Natural Language Processing With Neural Networks</i>

Sumário

1	INTRODUÇÃO	9
1.1	Objetivos	10
1.1.1	Objetivos Específicos	10
2	ANÁLISE DE SENTIMENTO	11
2.1	Etapas da análise de sentimento	12
2.1.1	Identificação	12
2.1.2	Classificação	13
2.1.3	Sumarização	13
2.2	Abordagens Supervisionada e Não Supervisionada	14
2.3	Níveis da análise de sentimento	15
2.3.1	Análise de sentimento em nível de documento	16
2.3.2	Análise de sentimento em nível de sentença	16
2.3.3	Análise de sentimento baseada em aspectos	16
2.3.4	Análise comparativa de sentimentos	18
2.3.5	Abordagem Baseada em Dicionário	18
2.4	Áreas de aplicação de análise de sentimento	20
2.5	Principais Ferramentas	22
2.5.1	Weka	23
2.5.2	Repustate	23
2.5.3	Sentiment140	23
3	ANÁLISE DE SENTIMENTO APLICADA A RESENHAS DE LIVROS	24
3.1	Base de dados analisada	24
3.2	Critérios de Avaliação	27
3.3	Resultados	27
3.3.1	FREQ Baseline	28
3.3.2	Hu & Liu	29
3.3.3	FREQ Baseline + <i>Word2Vec</i>	32
3.4	Discussão	33
4	CONCLUSÃO	36
	REFERÊNCIAS	37

1 Introdução

Durante o processo de evolução da *internet* seus usuários deixaram de ser apenas receptores de conteúdo e se tornaram agentes ativos, pois além de visualizar passaram a interagir, compartilhar e produzir conteúdo. A partir daí tornou-se cada vez mais importante e valiosa a interação dos usuários com as plataformas digitais (redes sociais, *e-commerce*, *streaming*, *blogs*) que estimula-os a deixarem suas opiniões, sentimentos, ou experiências sobre um produto, um lugar ou mesmo um serviço (PEREIRA; MARINHO; SEGUNDO, 2022).

O resultado gerado por meio do processamento de dados na *internet* causa um impacto muito forte no poder de decisão das pessoas, que ao procurarem por um produto primeiramente vão em busca de avaliações, discussões e comentários em ambientes digitais que expressam a satisfação e conseqüentemente o sentimento das pessoas quanto a aquisição de um produto (TRIPATHY et al., 2022).

Segundo Buzzo, Prado et al. (2021), 80% dos dados de textos do mundo provenientes de bate-papo, *e-mail*, mídias sociais, *blogs*, artigos, entre outros, não estão organizados. Organizar, analisar ou classificar esses dados é um processo financeiramente custoso e demanda bastante tempo.

A grande quantidade de dados não estruturados, resultante das interações de usuários na *internet*, impulsionou o desenvolvimento de técnicas e ferramentas para auxiliar no tratamento desses dados, a fim de se obter informações importantes para tomada de decisão (KAUER, 2016). Diante disso, a análise de sentimento atua como uma área de estudo, que desenvolve técnicas e ferramentas direcionadas para análise de opiniões, atitudes e emoções das pessoas. O resultado das análises que fazem uso dessa abordagem de sentimento, tem ganhado bastante espaço em pesquisas científicas, aplicações no cotidiano das pessoas e de empresas nos últimos anos (BUZZO; PRADO et al., 2021).

A análise de sentimentos também denominada de mineração de opinião, está diretamente relacionada com o processamento de linguagem natural (PLN), e a partir do ano de 2000 passou a ser alvo de pesquisas com maior frequência. Desde então, algumas soluções têm sido implementadas, como: previsão de resultado de eleições e bilheteria de filmes com base em dados de redes sociais e desempenho de vendas com análise de *blogs* (HONG; SKIENA, 2010).

Além de técnicas, a análise de sentimento trabalha com uma abordagem que explora alguns níveis em uma análise. O nível de sentença e o nível de aspecto são dois exemplos desta abordagem (LIU, 2012). O nível de sentença transforma um conjunto de dados em forma de frases, ou seja, termos compostos por mais de uma palavra (sentença), avalia o

sentimento e atribui uma polaridade (positiva ou negativa) (MACHADO, 2018).

O nível de aspecto possui uma abordagem mais interpretativa dos dados em análise, pois busca identificar os tópicos ou os assuntos relacionados, mesmo que não estejam explícitos no texto e conseqüentemente faz a atribuição de polaridade. Em contrapartida, essa abordagem apresenta uma complexidade maior do que os demais níveis de análise de sentimento e possui uma literatura escassa principalmente para língua portuguesa (KAUER, 2016).

Portanto, este trabalho produziu uma pesquisa com o propósito de contribuir com o desenvolvimento literário sobre a análise de sentimento e contextualiza seus conceitos por meio de um experimento realizado por Machado (2018), que adota uma abordagem supervisionada, sobre a análise de sentimentos em resenhas de livros.

1.1 Objetivos

Desenvolver um estudo sobre a análise de sentimentos, seus principais conceitos, aplicações e apresentar uma discussão com base em um estudo de caso apresentado na literatura.

1.1.1 Objetivos Específicos

- Apresentar os principais conceitos envolvidos na análise de sentimento, seus níveis de análise e etapas do processo;
- Apresentar e discutir uma aplicação de análise de sentimento, a nível de aspecto no contexto de resenhas de livros.

2 Análise de sentimento

Para [Medhat, Hassan e Korashy \(2014\)](#) a Análise de Sentimento (SA), também conhecida como mineração de opinião, é uma vertente de estudo no contexto da mineração de texto, que usa a abordagem computacional para tratar emoções, opiniões e subjetividade de texto. Dessa forma, busca conhecer aquilo que está atrelado ao sentimento em relação a uma determinada entidade que pode ser representada por eventos, tópicos e indivíduos.

Por outro lado, alguns autores como [Tsytsarau M; Palpanas \(2012\)](#) argumentam algumas diferenças entre a análise de sentimentos e a mineração de opiniões. Segundo eles, a primeira surgiu como uma atividade do Processamento de Linguagem Natural (PNL) em busca dos sentimentos contidos em textos. Já a segunda se dedica de forma mais intensa a extrair e processar as opiniões dos indivíduos em relação a alguma entidade, que pode ser um produto, serviço ou pessoa.

[Carvalho \(2014\)](#) afirma que a mineração de opinião tem dois principais objetivos. Um é fazer a identificação e distinção entre documentos que tem fatos, como notícias e documentos que contêm opiniões; o outro é classificar as opiniões em relação a sua polaridade.

A classificação da polaridade de uma palavra pode variar de acordo com a técnica empregada. No caso de técnicas estatísticas, uma palavra com polaridade positiva resulta da frequência de coocorrência de palavras com forte orientação positiva, como “*excelente*” ou “*ótimo*”. No entanto, se a frequência de coocorrência de palavras com forte orientação negativas como “*péssimo*” ou “*horrível*” for superior a de palavras positivas, a polaridade será negativa ([FILHO, 2014](#)).

Em decorrência do crescimento exponencial de aplicações comerciais, assim como as redes sociais, a análise de sentimento tem ganhado cada vez mais espaço. Motivada pelo interesse de descobrir dos usuários dessas aplicações o sentimento expresso através das opiniões ([LIU, 2012](#)).

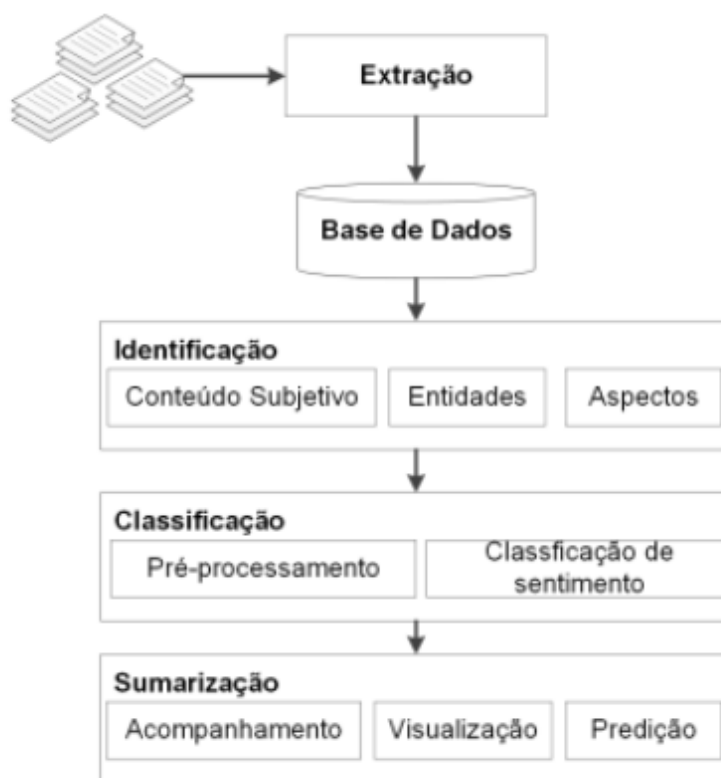
A análise de sentimento é uma ferramenta poderosa para uma abordagem de pesquisa. [Yu, Duan e Cao \(2013\)](#) elenca algumas justificativas do porquê usá-la. A primeira delas é a capacidade de converter grandes quantidades de dados em informações úteis para gerar previsões para determinado cenário. A segunda, permite construir modelos para agregar opiniões em massa, obter informações, identificar o comportamento e assim prever uma tendência futura.

2.1 Etapas da análise de sentimento

A análise de sentimento atua no problema de identificação de opiniões de determinados assuntos e avalia a polaridade. Essa atuação é a base onde outras atividades da análise de subjetividade podem ser construídas e através dos resultados processados pode definir e agrupar as opiniões. Assim, é muito importante que se tenha uma boa qualidade dos resultados, a fim de que cada etapa desse processo seja bem sucedida (TSYTSARAU M; PALPANAS, 2012).

Três etapas caracterizam o processo de análise de sentimento: identificar, classificar e sumarizar. Em cada uma dessas etapas ou atividades existem outros subprocessos que podem acontecer (TSYTSARAU M; PALPANAS, 2012). A representação desse processo pode ser visto na Figura 1 e uma explicação mais detalhada de cada etapa será apresentada.

Figura 1 – Etapas da análise de sentimento.



Fonte: Becker e Tumitan (2013)

2.1.1 Identificação

A partir de uma fonte de dados, que pode ser de alguma rede social ou sites de avaliação de produtos e serviços, a etapa de identificação opera com o objetivo de identificar os tópicos, aspectos e associar com o respectivo conteúdo. De acordo com a granularidade

da análise, identifica-se as entidades, os aspectos e os sentimentos presentes (BECKER; TUMITAN, 2013).

O nível de complexidade pode variar conforme o tipo de fonte de onde se extrai os dados. Jornais, *blogs* ou *posts*, podem apresentar uma maior complexidade, por não se conhecer previamente as entidades envolvidas, e com a possibilidade de apresentar várias entidades no mesmo texto. Já quando se trata de revisão de produtos e serviços, torna-se mais fácil a identificação do alvo, porque parte do pressuposto de que o documento está associado a uma única entidade (BECKER; TUMITAN, 2013).

Para casos em que a identificação não é direcionada a alvos definidos previamente, Sarawagi (2008) aponta que as técnicas de identificação de entidades nomeadas da recuperação de informações, podem ser utilizadas como recurso.

Portanto, a etapa de identificação também pode incluir a diferenciação entre conteúdo ou sentenças que podem ou não apresentar opinião, principalmente em situações cuja granularidade é menor. O processo de determinação do conteúdo de uma determinada opinião, na sua maioria, se dá em identificar a palavra ou classe de palavra que expressa sentimento (BECKER; TUMITAN, 2013) .

2.1.2 Classificação

No âmbito da classificação de sentimento, duas técnicas se destacam como abordagens principais: léxico de sentimento e aprendizado de máquina (TSYTSARAU M; PALPANAS, 2012). A classificação de sentimentos também é conhecida como classificação de polaridade, isso porque, geralmente aborda um aspecto binário de classificação, onde um texto pode ser positivo ou negativo (BECKER; TUMITAN, 2013) .

Apesar disso, a classificação não se limita a esse fator binário, pois a análise pode envolver outras classes, no intuito de se obter melhores resultados. Sendo que tais classes podem ser distribuídas em níveis (*muitoPositivo* ou *moderadamentePositivo*) de intensidade, na classificação ou até mesmo representações fracionárias (BECKER; TUMITAN, 2013) .

Existe também uma abordagem que incide sobre a categoria neutra, que envolve texto que não possui uma tendência clara quanto a polaridade, ou seja, não tem sentimento (BECKER; TUMITAN, 2013). Dito isso, é importante destacar que um texto neutro é diferente de um texto que não tem polaridade. A diferença é que o não polarizado não contém elementos suficientes para classificá-lo, como positivo, negativo ou neutro (DEY; HAQUE et al., 2009) .

2.1.3 Sumarização

Becker e Tumitan (2013) descreve o objetivo desta etapa como sendo a criação de métricas que configuram o sentimento geral, que inclusive pode ser utilizado como entrada

para outras aplicações. Esse processo demanda uma grande quantidade de dados (opiniões) para que se tenha uma média ou uma polaridade predominante em relação à entidade em análise.

Sausen (2016) apresenta que a sumarização tem como função, transformar e minerar os dados coletados de modo que o usuário compreenda as informações geradas desse processo. Além disso, converter para métricas que evidencie o potencial do sentimento dos dados. Assim, o aumento contínuo e expressivo de dados subjetivos tem sido um forte estímulo para aplicação da sumarização.

“ Muitas são as aplicações centradas na sumarização e visualização do sentimento, ou na predição de comportamentos com base no sentimento existente. Empresas, eventos (e.g. Olimpíadas), personalidades, estão interessadas na compreensão de como são percebidas pelo público em geral em tempo real, e nas mais variadas mídias (BECKER; TUMITAN, 2013) .“

2.2 Abordagens Supervisionada e Não Supervisionada

A análise de sentimentos emprega principalmente duas abordagens, a supervisionada e a não supervisionada. A abordagem supervisionada, resulta de um treinamento onde os dados analisados possuem as respostas desejadas (DOMINGUES, 2003). Isso significa dizer que os dados são anotados com as respostas. Então quando se aplica essa abordagem tenta-se prever através de um conjunto de variáveis independentes uma variável dependente, como mostra a Tabela 1 (FACURE, 2022).

Tabela 1 – Exemplo de abordagem supervisionada

Variáveis independentes	Variável dependente
Anos de Carreira, Formação, Idade	Salário
Idade do Carro, Idade do Motorista	Risco de Acidente Automotivo
Texto de um livro	Escola Literária

Fonte: Facure (2022)

A classificação supervisionada dispõe de técnicas que geralmente são aplicadas no problema de classificação de sentimentos. No entanto, requer volumes grandes de dados de treinamento rotulados e para se obter esses dados rotulados pode ser caro e demorado (AUE; GAMON, 2005). Vários métodos de mineração empregam esse tipo de aprendizado e predominantemente as técnicas usadas são preditivas, a medida que se dedicam a prever qual a classe de uma determinada instância não vista, com base nos dados usados no treinamento (DAMASCENO, 2022).

Dado um conjunto de dados, os classificadores ajudam a determinar o valor de um atributo a partir de um subconjunto de atributos contidos nesse conjunto de dados. Para isso, considere que deseja-se descobrir o perfil de clientes que alugam mais de três filmes, em uma locadora, ou fazer a previsão de clientes que aceitariam aderir a um programa de mensalidade referente a aluguéis de filmes (DAMASCENO, 2022).

A segunda abordagem (não supervisionada) da análise de sentimento dispõe apenas dos padrões de entrada e está ligada ao aspecto semântico, com base em coleções de palavras criadas previamente. Os elementos que compõem essas coleções podem ser termos positivos ou negativos, de modo que seja possível a identificação automática da polaridade através da frequência dos termos contidos no texto em questão. Dessa forma, elimina-se a necessidade de que uma base de dados seja classificada previamente (YU; DUAN; CAO, 2013) (MEIRELES; CENDÓN, 2011) .

Para exemplificação do aprendizado não supervisionado, considere que deseja-se conhecer o perfil de clientes de um determinado comércio. Nesse caso, para cada compra feita não se tem anotado qual o perfil desse cliente. Pode haver um perfil de cliente que compra leite em pó e fralda, outro que compra vinho e queijo, ou que compra carne e carvão. Por isso, o aprendizado não supervisionado terá que descobrir os perfis sem os dados anotados previamente (FACURE, 2022).

Nesse contexto, percebe-se que não foi especificado como se caracteriza cada perfil de cliente. Para isso, a abordagem não supervisionada irá através, de algum algoritmo, tentar identificar as diferenças e semelhanças entre os dados, de modo que se tenha uma melhor categorização dos perfis de clientes (TECH, 2022).

2.3 Níveis da análise de sentimento

Existe uma grande demanda por parte de usuários *online*, que precisam da análise de sentimento. Em abril de 2013, 90% das decisões de clientes dependiam de *reviews* na *internet*, daí percebe-se a importância de avaliações de sentimento, que influencia diretamente a compra de um produto ou serviço (PENG et al., 2014) .

Junto aos benefícios proporcionados pela análise de sentimento, manifestam-se vários desafios, como decifrar as estruturas de textos, encontrar conteúdos específicos em relação ao que se busca, classificar a polarização (positivo ou negativo) das informações, agrupar e organizar em uma linguagem compreensível ao usuário final (BECKER; TUMITAN, 2013). Diante disso, a análise de sentimento trabalha com níveis, onde de acordo com o propósito da análise ou da fonte de extração de dados, melhor se aplica algum desses níveis, que são eles:

2.3.1 Análise de sentimento em nível de documento

Parte da premissa de que o texto de um documento, como um todo, está associado a um único assunto e tem uma determinada polaridade (positivo, negativo ou neutro). Mesmo diante da possibilidade de um texto possuir várias entidades, opiniões e conseqüentemente expressar diversos sentimentos, o foco está na classificação de sentimento do documento (LIU; ZHANG, 2012).

2.3.2 Análise de sentimento em nível de sentença

Enquanto que a análise a nível documento é mais abrangente, por dar ênfase ao todo e não nas pequenas partes de um documento, a análise a nível de sentença é bem mais minuciosa, pois em um documento geralmente tem-se muitas sentenças (frases, termos compostos) e cada uma delas é alvo desse nível de análise. Dessa forma, as sentenças são avaliadas e classificadas de acordo com a polaridade do sentimento que expressam (LIU, 2012).

É comum usar o nível de sentença em situações cujo documento em análise apresenta várias opiniões, pois cada termo pode apresentar uma opinião ou conter um sentimento e assim a qualidade da análise aumenta, frente à análise a nível de documento (THET; NA; KHOO, 2010).

2.3.3 Análise de sentimento baseada em aspectos

Também conhecida como análise de sentimentos baseada em recursos, busca identificar todas as expressões de sentimentos contidas em um documento ou sentença e determinar a polaridade. Dessa forma, é possível obter o máximo de detalhes sobre todas as entidades (pessoa, produto, qualidade, etc) e elementos mencionados em um texto (FELDMAN, 2013).

Segundo Machado (2018) existem dois tipos de aspectos. O primeiro é o explícito, refere-se aqueles que são mencionados de forma clara em uma frase. Por exemplo, na seguinte oração “*Peguei dengue e estou com febre alta*”, o termo “*febre*” é um aspecto explícito. O segundo é implícito, refere-se aqueles que são mencionados de forma indireta em uma frase. Por exemplo, na oração “*A vacina contra dengue é cara*”, o termo “*preço*” é um aspecto implícito presente na frase, resultado da inferência do termo qualificador “*cara*”.

Neste trabalho será abordado um experimento que aplicará a análise de sentimento baseado em aspectos. Desta forma, serão apresentados três métodos utilizados no experimento, considerando a abordagem de aspectos:

1. FREQ Baseline

Caracteriza-se por ser baseado no cálculo da frequência de substantivos e sintagmas nominais quanto a sua ocorrência em um texto ou documento. Com base nisso, um mecanismo de poda é aplicado à medida que os termos mais frequentes são encontrados e assim o processo de poda mantém apenas os substantivos e sintagmas nominais que apresentam uma frequência igual ou superior a um valor pré-estabelecido (frequência de corte) (PAVLOPOULOS; ANDROUTSOPOULOS, 2014). Esse método atua como um filtro de frequência com parâmetros previamente definidos, para evitar que todas as ocorrências de determinado termo sejam considerados como aspecto (MACHADO, 2018) .

2. Hu & Liu

Segundo Machado (2018) esse método utiliza a abordagem de frequência de substantivos e sintagmas nominais tal como o *FREQ Baseline*. Adicionalmente, ele combina essa abordagem com regras de detecção de termos compostos, associado a remoção de termos candidatos não relacionados. Dessa forma, pode identificar termos mais longos e termos menos frequentes, podendo corrigir ou eliminar termos que de maneira errada podem ser identificados como aspectos.

3. *FREQ Baseline + Word2Vec*

O *Word2Vec* é um método que busca implementar uma maior eficiência na criação de modelos de representação de palavras por meio de vetores em grandes conjuntos de dados. Esses vetores são representações semânticas das palavras e são consideradas como variáveis latentes, onde cada vetor representa uma dimensão do significado da palavra. O *Word2Vec* dispõe de um modelo de linguagem preditivo, oriundo de uma arquitetura de redes neurais que computacionalmente é muito eficiente. O processo de predição método se dá a partir de seus vizinhos com base nos vetores aprendidos. Como já foi apresentado, o método *FREQ Baseline* é fundamentado na frequência dos termos e isso dá margem a muitos ruídos, pois termos que aparecem em um texto, mas, que não estão relacionados ao assunto em questão, muitas vezes são identificados como aspectos. Com o propósito de evitar esse problema que Pavlopoulos e Androutsopoulos (2014) desenvolve um exemplo e implementa uma função de detecção de contexto, embasada na representação dos termos em espaço vetorial contínuo, de acordo com o modelo *Word2Vec* descrito acima (MIKOLOV et al., 2013). Além de inserir no processo uma etapa de poda para evitar aspectos não relacionados ao contexto da análise (PAVLOPOULOS; ANDROUTSOPOULOS, 2014) .

2.3.4 Análise comparativa de sentimentos

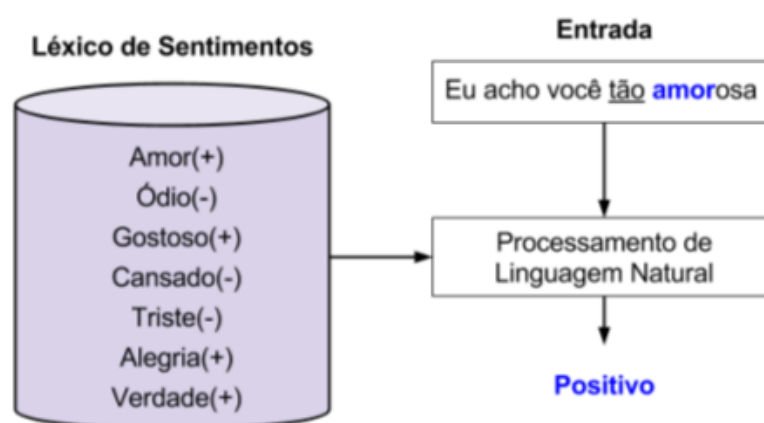
Em casos como: “*Este computador Apple aparenta ser bem melhor do que aquele Asu*”, não expressam diretamente uma opinião, mas primeiramente uma comparação e associado a isso emite uma opinião. Neste cenário, a abordagem comparativa busca identificar o sentimento em sentenças que trata-se de uma comparação. E através de termos linguísticos usados para se fazer comparação é possível extrair o sentimento, ou seja, a polaridade em relação aos produtos (entidades) alvos da comparação (BENEVENUTO; RIBEIRO; ARAÚJO, 2015).

2.3.5 Abordagem Baseada em Dicionário

Também conhecida como léxica ou linguística essa abordagem tem como aspecto principal a utilização de léxicos de sentimentos, ou seja, dicionários. Os mesmos consistem em conjuntos de palavras ou expressões de sentimentos que possuem uma determinada polaridade (BECKER; TUMITAN, 2013).

Benevenuto, Ribeiro e Araújo (2015) mostra que ao invés desse tipo de abordagem conter o significado de cada palavra como um conteúdo, dispõe de uma atribuição quantitativa para cada palavra. Costuma-se usar valores entre -1 e 1, representando um sentimento negativo e positivo respectivamente. A Figura 2 é uma representação do funcionamento dessa abordagem, que também assume que palavras individuais são constituídas de polaridade prévia, ou seja, pode ser expressa por um valor numérico independente do contexto.

Figura 2 – Abordagem baseada em dicionário.



Fonte: Benevenuto, Ribeiro e Araújo (2015)

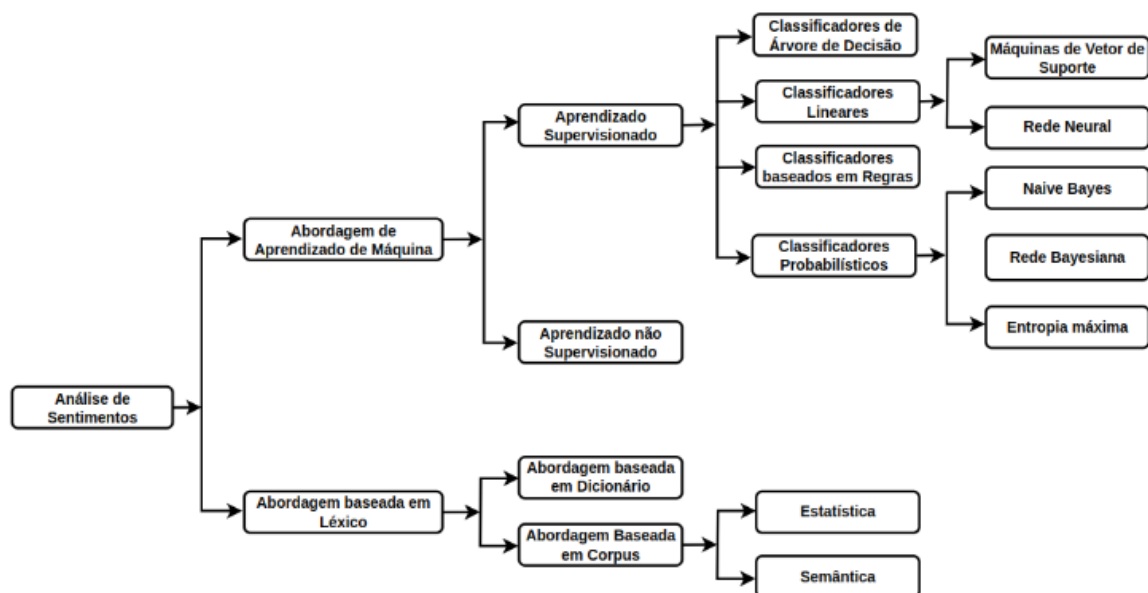
Feldman (2013) elenca três maneiras de obter o léxico de sentimentos: a primeira através de abordagens manuais, onde indivíduos codificam o léxico. A segunda maneira é baseada em dicionários em que um conjunto de palavras é expandido e a terceira, é

baseada em *corpus*, onde um conjunto de palavras é expandido através de um grande *corpus* de documento referente a um único domínio.

Para Becker e Tuminan (2013) a coocorrência é um dos métodos mais usados ao não levar em consideração a ordem dos termos em um documento, nem suas relações léxico-sintáticas. A classificação do texto em relação ao seu sentimento, se dá mediante palavras de sentimentos e sua polaridade é dada por um léxico de sentimentos.

Na Figura 3 Medhat, Hassan e Korashy (2014) apresentam uma classificação da análise de sentimento envolvendo as principais técnicas que a mesma utiliza. Nessa estrutura, a base é formada pela abordagem de aprendizado de máquina, abordagem léxica e híbrida. A abordagem de aprendizado de máquina agrega vários algoritmos e também faz uso de recursos linguísticos.

Figura 3 – Técnicas de classificação de sentimentos.



Fonte: Adaptado de Medhat, Hassan e Korashy (2014)

A abordagem léxica é fundamentada em coleções de termos já existentes que expressam algum sentimento. Também se divide em duas sub abordagens, dicionário e *corpus*. A abordagem de *corpus*, aborda tanto métodos estatísticos quanto semânticos, de maneira individual.

Percebe-se que o aprendizado supervisionado dispõe da maioria das técnicas no contexto dessa classificação apresentada. Destaca-se: árvore de decisão, classificadores baseados em regras, classificadores probabilísticos que abrange outras técnicas - *Naives Bayes*, Rede Bayesiana, Entropia máxima - e classificadores lineares distribuídos em Rede Neural e Máquinas de Vetor de Suporte (RUSTAMOV; MUSTAFAYEV; CLEMENTS, 2013). Tais técnicas são com maior frequência usadas em estudos e pesquisas no âmbito

da mineração de dados e conseqüentemente na análise de sentimentos.

2.4 Áreas de aplicação de análise de sentimento

Segundo [Feldman \(2013\)](#), a área de avaliação de produto e serviço de consumo é um dos principais focos de aplicações da análise de sentimento. Para isso, existem várias plataformas que oferecem serviços automatizados voltados para essa área, a exemplo, o *Google Product Search*. Um outro aspecto bastante explorado é no âmbito do mercado financeiro, em que várias fontes como artigos, *blogs*, tweets são usadas como referência de dados para análise de sentimentos de empresas ou mesmo para sistema de negociação automatizado.

Redes sociais como *Twitter* e *Facebook* têm sido comumente objetos de estudo da análise de sentimentos. Nesse contexto, geralmente são capturadas informações a fim de medir a reputação de uma pessoa, marca ou outra entidade ([FELDMAN, 2013](#)).

Segue-se alguns exemplos onde a análise de sentimento tem sido amplamente empregada tanto em processos que envolvem uma empresa quanto ao cotidiano das pessoas:

- **Avaliações de produto:** quando se trata de avaliações de produtos existe um número significativo de trabalhos envolvendo essa abordagem. O interesse crescente sobre esse aspecto se dá devido aos impactos positivos que podem gerar na vendas de produtos, no melhoramento das estratégias de *marketing*, na influência de tomada de decisão do cliente e previsão de vendas ([PENG et al., 2014](#)).

[Santos et al. \(2010\)](#) usou o algoritmo SVM para verificar o quanto os usuários expressam suas opiniões sobre um determinado produto. O SVM foi treinado com uma coleção de mensagens classificadas manualmente, com polaridade neutra ou opinativa.

- **Reputação de marcas:** [Evangelista e Padilha \(2014\)](#) mostra a forte utilização das redes sociais, por meio das marcas (empresas), que usam como ferramenta para fortalecer sua identidade e ao mesmo tempo divulgar produtos e serviços. Esse espaço digital e social é fundamental na construção de uma boa reputação das marcas e também de bons relacionamentos com os consumidores.

Sendo assim, [Evangelista e Padilha \(2014\)](#) desenvolve uma ferramenta que monitora a reputação de empresas de comércio eletrônico nas redes sociais. Através dos *posts* dos usuários no *Facebook* e *Twitter* a ferramenta reconhece padrões nos comentários e classifica como sendo positivo, neutro ou negativo.

- **Tendências políticas:** após a coleta de dados em várias fontes (*Twitter*, *Facebook* e *Instagram*), Ramteke et al. (2016) desenvolve um trabalho para avaliação de tendência política (previsão de resultado eleitoral) nas redes sociais, medida através de opiniões dos usuários. Os algoritmos *Naive Bayes* e SVM são usados no processo de classificação. Os dados foram utilizados em forma de palavras e a análise de sentimento aplicada buscou identificar a polaridade da palavra.

Tumasjan et al. (2010) desenvolveu um estudo no contexto da eleição federal alemã para identificar a influência do *Twitter* para deliberação política e validar se as mensagens *online* expressam o sentimento político das pessoas. Nesse trabalho foi usado o LIWC como *software* de análise de texto e as mensagens catalogadas eram associadas a um partido ou a um político.

- **Mercado financeiro (Ações e Criptomoedas):** Shah, Isah e Zulkernine (2019) obteve uma precisão direcional de 70.59% em ações no mercado indiano, através da avaliação do sentimento de notícias. No processo, as notícias foram extraídas da *internet*, pré-processadas e por meio de um dicionário de sentimentos criado de forma manual, coletou-se o sentimento das notícias.

Com dados extraídos do *Twitter*, Oliveira et al. (2019) aplicou uma abordagem não supervisionada por meio de um léxico, para avaliar o sentimento e prever eventuais retornos, volatilidade e volume de negociações e índices, e carteiras de investidores. Para essa análise foram usados vários métodos, como: Rede Neural, Regressão Múltipla, Floresta Aleatória, SVM e *Ensemble*. Ambos na área de aprendizado de máquina, para se fazer a previsão dos parâmetros de mercado.

Filho (2019) propõe um modelo de classificação com base em mensagens do *Twitter*, a fim de analisar a movimentação do preço do *Bitcoin*, que é a criptomoeda com maior capitalização de mercado. Utilizou-se de algumas métricas para uma janela de tempo, para assim classificar se o preço sobe ou desce na próxima janela de tempo. O experimento exercitado dispõe de técnicas de aprendizado supervisionado e para classificação, rede neural *Perceptron* Multicamadas.

Através de várias referências de fontes de dados, a análise de sentimento auxilia em *insights* em relação ao mercado de ações, ao ajudar na tomada de decisão, com base em reações, frente às notícias. Dessa forma, nasce essa nova abordagem que avalia com base em dados o sentimento em torno das notícias e assim identificar os eventuais impactos (SHAH; ISAH; ZULKERNINE, 2019).

- **Fake news:** essa é uma das áreas de grande relevância em que a análise de sentimento tem-se aplicado e ganhado espaço. No entanto, Moraes, Sampaio e Charles (2019) aponta algumas limitações, pelo fato de se restringir ao aspecto da polaridade, que implica em dois fatores. O primeiro, os resultados obtidos pela detecção das *fake news*

voltados para polaridade, indicam pouca capacidade de distinção, quanto ao que é *fake* ou não. O segundo, indica que emoções em textos escritos mostram atributos psicológicos ou sociais do contexto do indivíduo, podendo dificultar o emprego dessa abordagem (TAUSCZIK; PENNEBAKER, 2010).

Nesse contexto das *fake news*, a análise de sentimento atua com uma ferramenta auxiliar, para as abordagens que exploram o aspecto linguístico e classificação gramatical (AJAO; BHOWMIK; ZARGARI, 2019).

- **Perfis de pessoas:** as redes sociais são uma grande fonte de informações de seus usuários, visto que, através dos perfis as pessoas compartilham muitas informações a respeito de trabalho, comportamento e família. A publicação dessas informações na sua maioria ficam públicas para qualquer indivíduo ter acesso, também se dá de forma espontânea, através de vínculos de amizades e compartilhamentos mútuos. Diante disso, é possível fazer análises de perfis das pessoas, saber traços de sua personalidade, conhecer suas opiniões e sentimentos (MACEDO, 2018).

Mediante a aplicação da análise de sentimento nesse tipo de entidade, toma-se conhecido as emoções positivas, que podem refletir opiniões favoráveis e indicar também que tal pessoa compartilha um conteúdo benéfico, útil ou proveitoso. Mas, podem refletir sentimentos negativos, e assim indicar um conteúdo inapropriado, nocivo, prejudicial ou perigoso (MACEDO, 2018).

- **Eventos:** a Copa do Mundo é um evento que atrai a atenção mundial das pessoas e conseqüentemente suas opiniões. Filho (2014) utilizou-se dessa entidade para mapear a opinião de usuários do *Twitter*. O trabalho desenvolvido aplicou o algoritmo *Naives Bayes* para mostrar o processo de mineração, coleta, estruturação e criação de um modelo de classificação.

2.5 Principais Ferramentas

Affde (2022) mostra que no cenário atual da análise de sentimentos existem muitas ferramentas acessíveis com muitos recursos, e que facilita bastante esse processo de análise. Isso possibilita a automatização de processos, fornece insights através dos resultados das análises e tornam-se uma necessidade para projetos de monitoramentos de mídias sociais.

No entanto, para ter acesso aos principais recursos que essas ferramentas fornecem, geralmente é necessário adquirir uma licença, que na sua maioria são caras. No entanto, existem algumas ferramentas gratuitas, mas que demandam um conhecimento mais apurado, para implementar as análises (AFFDE, 2022).

Linguagens de programação como *R* e *Python*, dispõem de várias bibliotecas e API's que fornecem recursos, para se implementar o processo de mineração de dados até

a análise de sentimentos. Isso, de forma gratuita, além de IDE's com recursos gráficos e estatísticos dinâmicos (BLAZ, 2017). Dentre as muitas ferramentas existentes, destaca-se algumas.

2.5.1 Weka

Weka (*Waikato Environment for Knowledge Analysis*) é uma das ferramentas de domínio público mais utilizadas na área de mineração de dados. Por ser desenvolvida na linguagem *Java*, permite rodar em várias plataformas (FERREIRA, 2010). Dispõe de um painel, que permite a implementação de novos algoritmos com suporte para manipular dados e avaliação, além de oferecer estrutura para aplicação de muitos algoritmos de aprendizagem (SAUSEN, 2016).

2.5.2 Repustate

Repustate é uma poderosa ferramenta de análise de sentimento, com suporte a vários idiomas. Dispõe de um mecanismo que antecede o processo de análise, que é a marcação de classes gramaticais, que foca na decomposição de blocos de texto e suas classes (AFFDE, 2022).

Através da API de análise de sentimento, pode-se incluir regras de classificação personalizadas, receber dados de treinamento para elaborar novas regras ou texto de usuários. Isso permite muita flexibilidade e compreensão da ferramenta, além de disponibilizar uma documentação bem detalhada. Por meio da documentação perceber-se como acontece o melhoramento das análises. Cada etapa tem o propósito de obter informações da sentença, como: marcação, lematização, polarização, negação e amplificadores (muito e sempre) (SILVA, 2019).

2.5.3 Sentiment140

Sentiment140 consiste em uma API de classificação de sentimentos específica para o *Twitter*, sendo capaz de identificar o sentimento na estrutura do corpo de um *tweet* de um usuário. Essa ferramenta também busca identificar o sentimento em relação a uma marca, a um produto ou serviço (JUNIOR, 2015).

O aprendizado de máquina é a abordagem principal onde o *Sentiment140* se estrutura, e atrelado a isso, usa alguns classificadores como o *Maximum Entropy*, *Naive Bayes* e o SVM para desenvolver suas análises de sentimentos. Um ponto interessante a se considerar são os *emoticons* com suas respectivas representações de sentimento, positivo ou negativo (JUNIOR, 2015).

3 Análise de sentimento aplicada a resenhas de livros

Neste capítulo será apresentado um experimento desenvolvido por [Machado \(2018\)](#), que consiste em uma aplicação que aborda a análise de sentimento especificamente no seu nível de aspecto. Com o objetivo de discutir os conceitos apresentados nas seções [2.1](#), [2.2](#) e [2.3.3](#), avaliar as etapas e o comportamento do nível aspecto no domínio de resenhas de livros. Dessa forma, foi tomada uma base de dados denominada *corpus* ReLi que compreende um compilado de resenhas de livros e autores diferentes.

De acordo com o que foi apresentado no capítulo 02, a análise de sentimento possui vários métodos que podem ser empregados em uma análise. Diante disso, a solução abordada no experimento fará a combinação desses diferentes métodos para os mesmos dados, a fim de identificar os métodos que apresentam os melhores resultados na identificação de aspectos nas resenhas.

Quando se trata do nível de aspectos a análise de sentimento dedica-se a identificar os contextos. Isso significa que diante de uma entidade qualquer (pessoa, produto, serviço, etc) busca-se identificar suas características ([LIU et al., 2007](#)). Com isso, há uma forte tendência em se aplicar essa abordagem para explorar textos opinativos relacionados a produtos e serviços ([POPESCU; ETZIONI, 2007](#)).

Assim como a seção [2.1](#) apresenta o processo da análise de sentimento, este experimento seguirá tais etapas em alguns momentos, e em outros pegará os dados pré-processados. Após a avaliação dos resultados do experimento de [Machado \(2018\)](#), se discutirá os resultados em função dos métodos e das combinações utilizadas na solução usada pelo autor. Portanto, os dados e processos que incidem sobre este trabalho serão descritos detalhadamente a seguir.

3.1 Base de dados analisada

O conjunto de dados usado neste experimento resulta do projeto Anotadores Semânticos que consiste em um *corpus* denominado ReLi. Esse projeto foi dirigido pelo professor Ruy Milidiú, membro do Departamento de Informática da PUC do Rio de Janeiro. O ReLi é composto por 1600 resenhas referentes a 13 livros de 7 autores diferentes ([FREITAS et al., 2012](#)).

As resenhas foram coletadas na *Skoob*, que é a maior rede social voltada para o público de leitores do Brasil. Por definição, as resenhas foram anotadas manualmente,

indicando a presença de opinião, do aspecto e também da sua polaridade. Portanto, como mostra a Tabela 2, foram obtidas um total de 259.978 palavras e 12.470 frases (MACHADO, 2018).

O *corpus* ReLi é uma base de dados relativamente pequena e para uma melhor consolidação dos testes com uma base mais robusta, foi criado um outro *corpus* denominado de ReLi estendido, para adicionalmente ser usado no experimento. O *corpus* ReLi estendido foi composto por 6.698 resenhas, 51.148 frases e 98.0640 palavras (MACHADO, 2018).

Tabela 2 – Composição do *corpus* ReLi distribuída em função dos autores quantidades de resenhas, frases e palavras

Autor	Título	Resenhas	Frases	Palavras
Stephenie Meyer	Crepúsculo	409	3.266	62.268
Thalita Rebouças	Fala sério, amiga!; Fala sério, amor!; Fala sério, mãe!; Fala sério, pai!; Fala sério, professor!	161	910	16.864
Sidney Sheldon	O Outro lado da meia-noite; O Reverso da Medalha; Se houver Amanhã	230	1.569	31.712
Jorge Amado	Capitães da Areia	187	1.348	32.117
George Orwell	1984	202	2.228	51.320
José Saramago	Ensaio sobre a Cegueira	271	1.991	42.152
J.D. Salinger	O Apanhador nos Campos de Centeio	140	1.158	23.725
Total		1.600	12.470	259.978

Fonte: Adaptado de Machado (2018)

Freitas et al. (2012) considera as seguintes etapas para fazer a anotação de opinião a nível da frase e do sintagma: identificação e anotação das frases que contêm opinião; identificação do alvo da opinião; identificação e anotação da polaridade do termo (palavras ou expressão) que contém opinião em relação ao aspecto. Nesse contexto, opiniões neutras foram desprezadas, apenas opiniões positivas e negativas foram consideradas.

Da mesma forma, Machado (2018) considera essas etapas abordadas por Freitas et al. (2012) para anotação das opiniões. No entanto, adiciona mais uma etapa, a identificação e anotação da polaridade das frases que contêm opinião. As anotações e marcações do *corpus* ReLi foram elaboradas por linguistas, ou seja, especialistas que de certa forma caracterizam-se por terem opiniões mais apuradas a respeito do conteúdo das resenhas.

Diante do total de frases apresentado na Tabela 2, tem-se a distribuição de polaridade das opiniões do *corpus* ReLi representada em termos quantitativos e percentuais na Tabela 3. Cerca de 25% do total de 12.470, eram frases opinativas. Quanto à polaridade positiva e negativa, representam 77% e 17% respectivamente. Outro ponto a se destacar, é

que as opiniões mistas, ou seja, aquelas que apresentam na mesma frase aspectos positivos e negativos, somam 5% (MACHADO, 2018).

Tabela 3 – Composição das frases em percentuais do *corpus* ReLi quanto a sua polaridade e presença de aspectos.

Dados do ReLi	Quantidade	Porcentagem
Frases opinativas positivas	2.433	77,34 %
Frases opinativas negativas	544	17,29 %
Frases opinativas mistas	169	5,37 %
Total de frases opinativas	3.146	100,00 %
Opiniões positivas sobre aspectos	4.268	80,67 %
Opiniões negativas sobre aspectos	1.023	19,33 %
Total opiniões sobre aspectos	5.291	100,00 %

Fonte: Machado, 2018

Quanto aos aspectos contidos nas frases, é importante destacar a frequência de sua aparição. Considerando a Tabela 4, percebe-se que há uma predominância de frases que não possuem aspectos, cerca de 82%. Enquanto que o percentual restante de 17%, que contém aspectos, na sua maioria apresenta apenas um aspecto na frase. Já a minoria, possui dois ou mais aspectos (MACHADO, 2018).

Tabela 4 – Composição da frases com a ocorrência ou não de aspectos no *corpus* ReLi.

Ocorrência Aspectos	Quantidade	Porcentagem
Frases sem aspectos	10.237	82,16 %
Frases com aspectos	2.233	17,91 %
Total de Frases	12.470	100,00 %
com apenas 1 aspecto	1.818	14,58 %
com 2 ou mais aspectos	415	3,33 %

Fonte: Machado, 2018

De modo mais detalhado, a Tabela 5 apresenta que a maior parte dos aspectos que compõem o *corpus* são simples, pois contém apenas um termo. Quando se explora os títulos dos livros, tem-se aspectos compostos com dois ou três termos com maior frequência.

Tabela 5 – Ocorrências de aspectos simples e compostos.

Composição Aspectos	Quantidade	Porcentagem
1 termo	2.347	84,73 %
2 termos	102	3,68 %
3 termos	71	2,56 %
mais que 4 termos	250	9,03 %
Total de Aspectos	2.770	100,00 %

Fonte: Machado, 2018

3.2 Critérios de Avaliação

Cada resenha do *corpus* ReLi foi classificada previamente, para se considerar apenas aquelas que possuíam aspectos. Quando o *corpus* ReLi foi submetido aos métodos descritos na seção 2.3.3, seus resultados foram comparados com a classificação manual, ou seja, o *corpus* anotado, para então, se elencar os pontos de convergência e divergência na identificação de aspecto.

Na extração dos aspectos, foi considerado as posições de início e fim das sentenças (SEBASTIANI, 2002). Além disso, foi calculado a precisão e revocação através da micro média e também a média harmônica entre a precisão e revocação (denominada de *medida f* neste trabalho). As fórmulas dos cálculos estão descritas na Tabela 6 (MACHADO, 2018).

Tabela 6 – Métricas de avaliação da precisão e revocação

Métricas	Fórmula
Precisão (P^μ)	$\frac{\sum_{c=1}^C vp_i}{\sum_{c=1}^C (vp_i + fp_i)}$
Revocação/micro média (R^μ)	$\frac{\sum_{c=1}^C vp_i}{\sum_{c=1}^C (vp_i + fn_i)}$

Fonte: Adaptado de Machado (2018)

Os cálculos realizados se deram em torno de alguns parâmetros estabelecidos para classificação dos dados. Os dados com aspectos corretos são classificados como verdadeiros positivos (*vp*), aqueles que não continham aspectos mas, foram classificados como tendo aspectos são os verdadeiros negativos (*vn*) (MACHADO, 2018). Já os classificados de maneira errada, são considerados como falsos positivos (*fp*) e falsos negativos (*fn*), aqueles que erroneamente não foram identificados como aspectos (SOKOLOVA; LAPALME, 2009). C representa a quantidade de c classes e i cada elemento nessas classes.

3.3 Resultados

Nesta seção são apresentados os resultados do experimento de Machado (2018) submetido a cada um dos métodos descritos na seção 2.3.3, com demonstrações gráficas, tabelas e também alguns exemplos com discussões quanto ao aspecto do sentimento identificado no texto.

O processo de experimentação se deu em torno das etapas citadas na seção 3.1, ou seja, a marcação de frases em relação a presença de opinião, os aspectos relacionados e a identificação da polaridade dos aspectos. Como resultado desse procedimento foram obtidas apenas 2.333 frases que continham opinião. Por ser pequeno o conjunto de dados resultante, também foi testado o *corpus* ReLi estendido composto por 51.149 frases (MACHADO, 2018).

No experimento realizado destacam-se duas etapas : identificação e pré-processamento, apresentadas na Figura 1. Na etapa de identificação, as entidades e os aspectos foram localizados, neste caso, relacionados ao contexto de livros. Na etapa de pré-processamento o *corpus* ReLi veio previamente com uma classificação morfológica e os dados dividido em *tokens*. Apesar disso, essa classificação foi descartada e o texto analisado novamente para que através do analisador morfológico do módulo NLPNET (*Natural Language Processing with neural networks*) fosse feita a marcação morfológica.

A composição dos dados do *corpus* ReLi estendido, foi acompanhada de mais processos até chegar aos *tokens*, incluindo a extração dos dados como mostra a Figura 1, visto que foram coletados diretamente da *internet*. No primeiro passo se removeu as tags HTML, em seguida foi aplicado a segmentação por meio de dois processos, a divisão de texto em frases e a divisão das frases em tokens por meio do NLTK (*Natural Language Toolkit 7*). Por fim, foi aplicada através do NLPNET a análise morfológica (MACHADO, 2018).

No experimento os conjuntos de dados foram submetidos e processados considerando os métodos já apresentados. Para cada método foram obtidos os seguintes resultados:

3.3.1 FREQ Baseline

Conforme foi descrito na seção 2.3.3, o método FREQ Baseline atua na análise das frequências de substantivos e sintagmas nominais. A partir dessa premissa gera uma lista, onde os termos com menor ocorrência são eliminados com base em um valor preestabelecido que Machado (2018) denomina de frequência de corte. O objetivo de aplicar essa frequência de corte é filtrar, eliminar ou minimizar os ruídos nos dados.

Influenciados por Liu et al. (2007) em um de seus estudos, muitos trabalhos na literatura adotaram 1% como frequência de corte. No entanto, para este trabalho Machado (2018) experimentou diferentes frequências de cortes variando entre 1% e 10%, considerando a precisão, revocação e *medida f* como métricas para os resultados.

Como a *medida f* é resultante do equilíbrio entre a precisão e revocação, dessa forma, foi considerada como uma melhor métrica para análise dos experimentos. Com isso, na busca por uma melhor frequência de corte dos valores entre 1% e 10%, 5% foi o que apresentou a maior *medida f* no experimento, com um valor de 55,81%, precisão de 64,39% e 49,25% de revocação como mostra a Tabela 7 (MACHADO, 2018).

Feita essa definição importante da frequência de corte de 5%, segue-se alguns exemplos de aspectos verdadeiros positivos, ou seja, que foram identificados corretamente no experimento:

- “*Um livro sensível, intenso e profundo.*”: o método identificou de modo correto o

Tabela 7 – Percentuais da precisão, revocação e *medida f* obtidos com o método FREQ Baseline

Frequência de Corte	Precisão	Revocação	Medida F
1%	20,07	39,89	26,71
2%	31,26	43,29	36,31
3%	41,42	48,92	44,86
4%	46,46	40,37	43,20
5%	64,39	49,25	55,81
6%	65,38	47,24	54,85
7%	66,21	44,13	52,96
8%	66,21	44,13	52,96
9%	66,97	40,04	50,11
10%	66,97	40,04	50,11

Fonte: Machado, 2018

termo “*livro*” como aspecto, que é o termo mais repetido no *corpus*.

- “*Em ‘O outro lado de a meia-noite’ o brilhante autor constrói uma história totalmente sólida de amor, ódio e vingança.*”: nesse caso, o termo identificado corretamente como aspecto é “*história*”, termo esse com uma forte ocorrência no *corpus* ReLi.

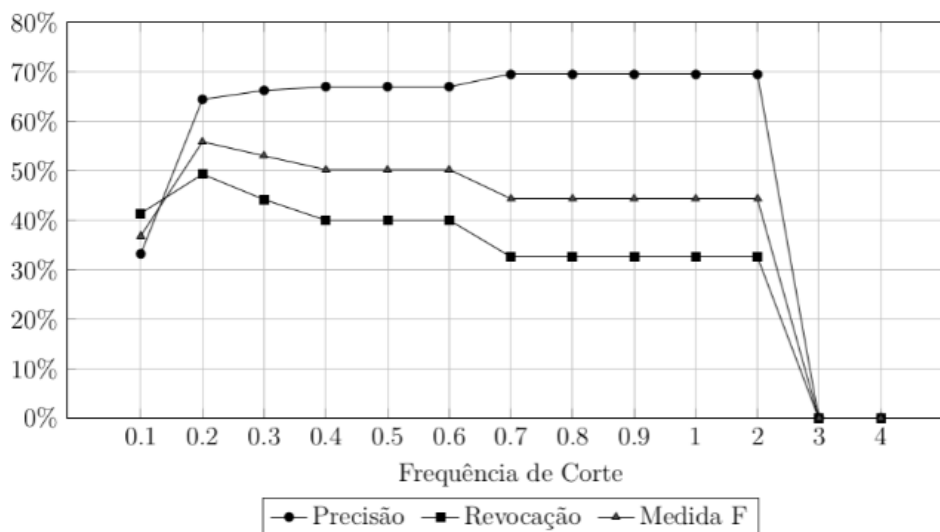
Para o exemplo a seguir o método não conseguiu identificar o aspecto correto, tendo um resultado falso positivo.

- “*Um livro brasileiro que tem crônicas excelentes pra se ler em alguns minutos e logo não querer parar de se ler.*”: para este caso o método identificou erroneamente o termo “*livro*” como aspecto, talvez por esse ser um dos termo com maior ocorrência no *corpus*. O aspecto correto esperado era o termo “*crônicas*”.

Tomando como base o *corpus* ReLi estendido foi realizado o mesmo experimento. Para esse caso, utilizou-se uma frequência de corte diferente da anterior, pois com frequência altas não foram encontrados aspectos de sentimento no texto. Diante disso, foi testado valores entre 0.1% e 4% como mostra a Figura 4, e 0.2% apresentou-se como o melhor resultado encontrado, com uma *medida f* de 55.81% que coincidiu com o valor encontrado anteriormente para o *corpus* ReLi (MACHADO, 2018) .

3.3.2 Hu & Liu

Conforme explicado na seção 2.3.3, o método Hu & Liu se apresenta com uma melhor capacidade de detecção de termos compostos e dispõe de um processo de poda com o propósito de corrigir e melhorar os seus resultados.

Figura 4 – Resultados do método FREQ Baseline com o *corpus* ReLi estendido.

Fonte: Autor: Machado, 2018

Na realização do primeiro experimento os resultados obtidos ficaram distantes do que era esperado, como mostra a Tabela 8. Algo interessante que se percebe é uma grande diferença nos resultados da *medida f*, para a mesma frequência de corte de 1% (comumente usada na literatura) entre os métodos FREQ Baseline e Hu & Liu. Enquanto que para o método FREQ Baseline a *medida f* foi 26,71%, para Hu & Liu foi de 46,44%, quase que o dobro (MACHADO, 2018).

Tabela 8 – Resultados obtidos usando o método Hu & Liu com *corpus* ReLi.

Frequência de Corte	Precisão	Revocação	Medida F
1%	37,79	60,22	46,44
2%	40,35	59,52	48,09
3%	42,66	59,41	49,66
4%	45,38	53,02	48,90
5%	46,34	52,25	49,11
6%	46,07	51,01	48,41
7%	45,41	49,03	47,15
8%	45,41	49,03	47,15
9%	44,64	46,76	45,68
10%	44,64	46,76	45,68

Fonte: Machado, 2018

Percebe-se também que os valores máximos e mínimos obtidos em cada métrica foram menores que os resultados do método FREQ Baseline. Uma das hipóteses que se elenca para justificar o ocorrido é de que esse método (Hu & Liu) é menos suscetível às variações diante da frequência de corte.

Com a lista de aspectos obtida, se analisou os resultados, e foram identificados

muitos sintagmas falsos positivos, ou seja, aspectos detectados de maneira incorreta. Então se desprezou os sintagmas nominais e novamente se aplicou o método e dessa vez os resultados foram melhores, como mostra a Tabela 9. Foi obtido uma *medida f* de 57.03% usando uma frequência de corte de 5%, que se mostrou como a melhor entre as frequências.

Tabela 9 – Resultados obtidos usando o método Hu & Liu com o *corpus* ReLi sem sintagmas.

Frequência de Corte	Precisão	Revocação	Medida F
1%	44,80	62,89	52,33
2%	49,81	62,12	55,29
3%	52,11	60,84	56,14
4%	57,73	54,88	56,27
5%	59,84	54,48	57,03
6%	59,93	53,42	56,49
7%	59,33	51,63	55,21
8%	59,33	51,63	55,21
9%	59,07	49,76	54,02
10%	59,07	49,76	54,02

Fonte: Machado, 2018

Alguns aspectos menos frequentes no *corpus* foram encontrados, conforme os exemplos a seguir:

- “*Mas gostei muito do final, compensa.*”: nessa frase o método identificou corretamente (verdadeiro positivo) o termo “*final*” como aspecto.
- “*A narrativa fica mais divertida a partir daí, se é que é possível.*”: o termo “*narrativa*” foi identificado corretamente como aspecto.

Apesar de um bom desempenho, o método apresentou algumas falhas. Segue-se alguns casos em que o método falhou:

- “*A narrativa é fluida*”: tem-se um caso falso negativo, pois para esta frase o método não identificou nenhum aspecto relacionado.
- “*O tipo de história divertida, narrativa empolgante, e aquele jeitinho brasileiro que a gente deveria valorizar mais.*”: o termo “*história*” foi corretamente identificado como aspecto, no entanto, esperava-se que o termo “*narrativa*” também fosse identificado como aspecto, mas, não foi.

O experimento foi realizado a partir do *corpus* ReLi estendido, da mesma forma quando usando apenas o *corpus* ReLi, no entanto, desprezou-se os sintagmas nominais. Os resultados se mostraram parecidos. Para uma frequência de corte de 0.5%, obteve-se a

maior *medida f*, de 45.68% dentre os valores testados. Ainda assim, os resultados com o *corpus* ReLi se mostraram melhores, utilizando a mesma frequência de corte.

3.3.3 FREQ Baseline + *Word2Vec*

Como foi discorrido na seção 2.3.3, esse método combina as características do método FREQ Baseline com a do *Word2Vec*, a fim de obter uma melhor eficiência nas análises, principalmente quando se tem termos mais longos ou termos menos frequentes. Neste caso, o método FREQ Baseline atuou na etapa de poda com base na rotina de detecção de contextos, com o propósito de descartar aspectos falsos positivos, ou seja, detectados erroneamente. Assim, os termos que pertencem ao contexto literário foram mantidos e os não pertencentes foram eliminados da lista de aspectos.

De acordo com a Tabela 10, percebe-se uma melhora significativa dos resultados, com base nas frequências de corte 1% e 3%, em comparação com o método FREQ Baseline. Através da poda aplicada pelo *Word2Vec* obteve-se 25.87% de precisão, já no experimento anterior como a mesma de frequência de 1% a precisão foi de 20.07%.


Tabela 10 – Resultados obtidos usando o método FREQ + *Word2Vec* com o *corpus* ReLi.

Frequência de Corte	Precisão	Revocação	Medida F
1%	37,62	25,87	30,66
2%	36,02	42,34	38,92
3%	47,33	48,01	47,67
4%	46,46	40,37	43,20
5%	64,39	49,25	55,81
6%	65,38	47,24	54,85
7%	66,21	44,13	52,96
8%	66,21	44,13	52,96
9%	66,97	40,04	50,11
10%	66,97	40,04	50,11

Fonte: Machado, 2018

O melhor resultado foi obtido com uma frequência de corte de 5% resultando em uma *medida f* de 55.81%, como mostra Figura 5. Obteve-se resultados iguais ao do método FREQ para as frequências de corte acima de 3%. O resultado alcançado evidencia que o método é capaz de identificar os aspectos relacionados, somente com base em suas frequências.

Para o *corpus* ReLi estendido, foram obtidos resultados parecidos. As frequências de cortes usadas foram entre 0.1% e 10% e após a execução do *Word2Vec*, percebeu-se que apenas na frequência de 0.1% a poda surtiu efeito, proporcionando um aumento na *medida f* de 36.80% para 39.37%. Para as demais frequências de corte os resultados foram

Figura 5 – Resultados obtidos usando o método *FREQ + Word2Vec* com o *corpus* ReLi.

Fonte: Machado, 2018

semelhantes aos do experimento usando somente o *corpus* ReLi, que para uma frequência de 0.2% obteve-se uma *medida f* de 55.81%, como mostra a Tabela 11.

Tabela 11 – Resultados obtidos usando o método *FREQ + Word2Vec* com o *corpus* ReLi estendido.

Frequência de Corte	Precisão	Revocação	Medida F
0,1%	38,35	40,44	39,37
0,2%	64,39	49,25	55,81
0,3%	66,21	44,13	52,96
0,4%	66,97	40,04	50,11
0,5%	66,97	40,04	50,11
0,6%	66,97	40,04	50,11
0,7%	69,45	32,50	44,28
0,8%	69,45	32,50	44,28
0,9%	69,45	32,50	44,28
1%	69,45	32,50	44,28
2%	69,45	32,50	44,28
3%	0,00	0,00	0,00
4%	0,00	0,00	0,00

Fonte: Machado, 2018

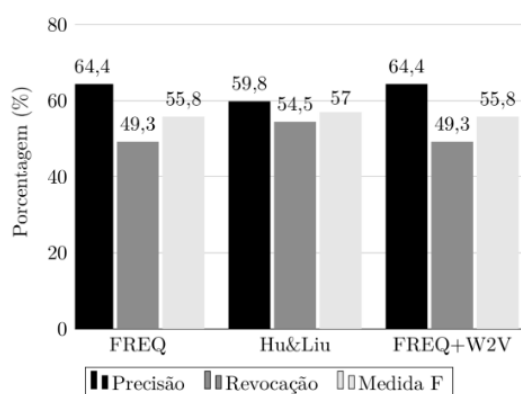
3.4 Discussão

De acordo com os resultados apresentados na seção 3.3 foi possível visualizar e compreender a complexidade, os desafios e a profundidade de informações que podem ser obtidas através da abordagem a nível de aspecto da análise de sentimentos, visto

que tal abordagem tem uma atuação interpretativa e não meramente quantitativa de um texto. Percebe-se que de acordo com o contexto, com o método, ou com a combinação de métodos, os resultados podem ser melhores, ou seja, mais próximos do que era esperado no experimento.


A utilização de uma abordagem supervisionada nos *corpus* ReLi e ReLi estendido, permitiu mapear em quais momentos se obteve maior ou menor assertividade, pois os resultados eram confrontados com os valores esperados. Também um dos pontos basilares para aplicação e performance dos métodos apresentados nas subseções 3.3.1, 3.3.2 e 3.3.3 foi a *medida f* descrita na seção 3.2, resultante da precisão e revocação que direcionou a escolha da melhor frequência de corte para cada situação. Dessa forma, esses melhores resultados estão representados graficamente e em percentuais nas figuras 6 e 7.

Figura 6 – Melhores resultados obtidos para os parâmetros precisão, revocação e medida f de cada método usando o *corpus* ReLi.



Fonte: Autor: Machado, 2018

Figura 7 – Melhores resultados obtidos para os parâmetros precisão, revocação e medida f de cada método usando o *corpus* ReLi Estendido.



Fonte: Autor: Machado, 2018

O método FREQ Baseline apesar de apresentar uma maior variação entre os valores

da precisão e revocação como mostra a Figura 6, se beneficiou da abordagem supervisionada e de seu mecanismo de poda conforme descrito no item 1 da seção 2.3.3, o que levou a obtenção de bons resultados quanto à identificação de aspectos. No entanto, usar esse método em um contexto não supervisionado não seria muito indicado, por haver uma forte dependência da frequência de corte.

Diferente do *FREQ Baseline*, o método *Hu & Liu* apresentou a menor variação entre precisão e revocação, o que significa uma menor dependência da frequência de corte e mostra-se adequado para um contexto não supervisionado. Essa melhor performance frente ao *FREQ Baseline* pode está associada ao fato de *Hu & Liu* implementarem uma maior capacidade de identificar termos mais longos e menos frequentes, além de corrigir termos errados que eventualmente poderiam ser considerados aspectos, conforme o item 2 da seção 2.3.3.

Quanto ao método *Word2Vec* com o *FREQ Baseline* usados em conjunto, teve um resultado semelhante ao do *FREQ Baseline* usado individualmente. Isso mostra que apenas usar mais de um método em uma análise não implica em um melhor resultado. É necessário identificar outras variáveis ou variações importantes no contexto, tal como esse experimento fez na frequência de corte e considerá-las na aplicação de um método.

4 Conclusão

Este trabalho desenvolveu um estudo sobre os conceitos, os níveis, as etapas e os principais métodos e ferramentas da análise de sentimentos, com ênfase na análise de sentimento a nível de aspecto. Para ilustrar a aplicação destes conceitos, tomou-se como base um trabalho elaborado por Machado (2018), onde é desenvolvido um experimento com uma abordagem supervisionada que implementa diferentes métodos baseados na análise a nível de aspectos. Em seguida, os resultados do experimento foram avaliados e discutidos considerando os métodos e a abordagem supervisionada.

A análise de sentimento mostrou-se uma ferramenta valiosa na transformação de dados não estruturados em informações. Dessa forma, gera valor para pessoas ou empresas a medida que traduz sentimentos através de dados e auxilia nas decisões. Junto a isso, a análise de sentimento a nível de aspecto apresentou-se como um instrumento conceitual capaz de explorar de maneira mais profunda os assuntos, temas, tópicos e questões que envolvem um texto. O uso de métodos supervisionados com uma base de dados anotada permitiu analisar seus comportamentos e resultados frente ao que era esperado.

Com base na pesquisa realizada e nas discussões apresentadas, consideramos que os objetivos deste trabalho foram alcançados, em função da análise de sentimento. É importante ressaltar que o experimento explorou vários métodos aplicados na mesma base de dados, em busca de melhores resultados. Também destaca-se que o método Hu & Liu apresentou os melhores resultados, principalmente por ter uma baixa dependência da frequência de corte.

A importância da análise de sentimento, assim como o seu nível de aspecto se confirmaram através do experimento, pois apresentaram resultados coerentes e próximos do esperado. Uma proposta relevante a se considerar em outros experimentos, em possíveis trabalhos futuros, seria adotar classificadores lineares como redes neurais, agregar bases de dados mais robustas e aplicar uma abordagem não supervisionada, como descrito na seção 2.2, a fim de se fazer um comparativo entre os dois experimentos e avaliar a assertividade de cada uma abordagem.

Referências

- AFFDE. As melhores ferramentas de análise de sentimento de ia em 2021. *Disponível: <https://www.affde.com/pt/best-sentiment-analysis-tools.html>*, Acesso: Abril, 2022. 22, 23
- AJAO, O.; BHOWMIK, D.; ZARGARI, S. Sentiment aware fake news detection on online social networks. In: IEEE. *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. [S.l.], 2019. p. 2507–2511. 22
- AUE, A.; GAMON, M. Customizing sentiment classifiers to new domains: A case study. In: CITESEER. *Proceedings of recent advances in natural language processing (RANLP)*. [S.l.], 2005. v. 1, n. 3.1, p. 2–1. 14
- BECKER, K.; TUMITAN, D. Introdução à mineração de opiniões: Conceitos, aplicações e desafios. *Simpósio brasileiro de banco de dados*, v. 75, 2013. 12, 13, 14, 15, 18, 19
- BENEVENUTO, F.; RIBEIRO, F.; ARAÚJO, M. Métodos para análise de sentimentos em mídias sociais. *Sociedade Brasileira de Computação*, 2015. 18
- BLAZ, C. C. A. Análise de sentimentos em tíquetes para o suporte de ti. 2017. 23
- BUZZO, C. C. de O.; PRADO, S. C. C. et al. Estudo comparativo dos algoritmos de aprendizado de máquina naive bayes e máquinas de vetores de suporte aplicados a análise de sentimentos. In: *Congresso de Tecnologia-Fatec Mococa*. [S.l.: s.n.], 2021. v. 5, n. 2. 9
- CARVALHO, J. D. S. Uma estratégia estatística e evolutiva para mineração de opiniões em tweets. 2014. 11
- DAMASCENO, M. Introdução a mineração de dados utilizando o weka. *Disponível: <http://connepi.ifal.edu.br/ocs/index.php/connepi/CONNAPI2010/paper/viewFile/258/207>*, Acesso: Maio, 2022. 14, 15
- DEY, L.; HAQUE, S. et al. Opinion mining from noisy text data. *International Journal on Document Analysis and Recognition (IJ DAR)*, Springer, v. 12, n. 3, p. 205–226, 2009. 13
- DOMINGUES, M. L. C. S. Mineração de dados utilizando aprendizado não-supervisionado: um estudo de caso para bancos de dados da saúde. 2003. 14
- EVANGELISTA, T. R.; PADILHA, T. P. P. Monitoramento de posts sobre empresas de e-commerce em redes sociais utilizando análise de sentimentos. In: SBC. *Anais do III Brazilian Workshop on Social Network Analysis and Mining*. [S.l.], 2014. p. 152–163. 20
- FACURE, H. H. P. Y. M. Os três tipos de aprendizado de máquina. *Disponível: <https://lamfo-unb.github.io/2017/07/27/tres-tipos-am/>*, Acesso: Maio, 2022. 14, 15
- FELDMAN, R. Techniques and applications for sentiment analysis. *Communications of the ACM*, ACM New York, NY, USA, v. 56, n. 4, p. 82–89, 2013. 16, 18, 20
- FERREIRA, E. d. B. A. Análise de sentimento em redes sociais utilizando influencia das palavras. *Trabalho de Graduação-Universidade Federal de Pernambuco-UFPE. Departamento de Ciência da Computação*, v. 22, p. 23–25, 2010. 23

- FILHO, J. A. C. Mineração de textos: análise de sentimentos utilizando tweets referentes à copa do mundo 2014. 2014. [11](#), [22](#)
- FILHO, W. B. S. Prevendo o preço do bitcoin com redes neurais usando dados do twitter e de mercado. Universidade Federal de Uberlândia, 2019. [21](#)
- FREITAS, C.; MOTTA, E.; MILIDIÚ, R.; CÉSAR, J. Vampiro que brilha... rá! *Desafios na anotação de opinião em um corpus de resenhas de livros*, v. 11, 2012. [24](#), [25](#)
- HONG, Y.; SKIENA, S. The wisdom of bookies? sentiment analysis versus. the nfl point spread. In: *Fourth International AAAI Conference on Weblogs and Social Media*. [S.l.: s.n.], 2010. [9](#)
- JUNIOR, S. J. da S. Aplicação de recuperação de informação e análise de sentimentos para suporte à pesquisas de mercado. 2015. [23](#)
- KAUER, A. U. Análise de sentimentos baseada em aspectos e atribuições de polaridade. 2016. [9](#), [10](#)
- LIU, B. Sentiment analysis and opinion mining. *Synthesis lectures on human language technologies*, Morgan & Claypool Publishers, v. 5, n. 1, p. 1–167, 2012. [9](#), [11](#), [16](#)
- LIU, B.; ZHANG, L. A survey of opinion mining and sentiment analysis. In: *Mining text data*. [S.l.]: Springer, 2012. p. 415–463. [16](#)
- LIU, Y.; HUANG, X.; AN, A.; YU, X. Arsa: a sentiment-aware model for predicting sales performance using blogs. In: *Proceedings of the 30th annual international ACM SIGIR conference on Research and development in information retrieval*. [S.l.: s.n.], 2007. p. 607–614. [24](#), [28](#)
- MACEDO, F. C. d. Análise de sentimentos em redes sociais: uma abordagem baseada em emoções. 2018. [22](#)
- MACHADO, M. T. *Estudo e avaliação de métodos de análise de sentimentos baseada em aspectos para textos opinativos em português*. Tese (Doutorado) — Universidade de São Paulo, 2018. [10](#), [16](#), [17](#), [24](#), [25](#), [26](#), [27](#), [28](#), [29](#), [30](#), [36](#)
- MEDHAT, W.; HASSAN, A.; KORASHY, H. Sentiment analysis algorithms and applications: A survey. *Ain Shams engineering journal*, Elsevier, v. 5, n. 4, p. 1093–1113, 2014. [11](#), [19](#)
- MEIRELES, M. R. G.; CENDÓN, B. V. Categorização e classificação de documentos a partir de suas citações: uma proposta baseada em redes neurais artificiais. *DataGramaZero (Rio de Janeiro)*, v. 12, p. 2, 2011. [15](#)
- MIKOLOV, T.; CHEN, K.; CORRADO, G.; DEAN, J. Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*, 2013. [17](#)
- MORAES, M. P.; SAMPAIO, J. de O.; CHARLES, A. C. Data mining applied in fake news classification through textual patterns. In: *Proceedings of the 25th Brazillian Symposium on Multimedia and the Web*. [S.l.: s.n.], 2019. p. 321–324. [21](#)

- OLIVEIRA, D. J. S.; BERMEJO, P. H. d. S.; PEREIRA, J. R.; BARBOSA, D. A. A aplicação da técnica de análise de sentimento em mídias sociais como instrumento para as práticas da gestão social em nível governamental. *Revista de Administração Pública*, SciELO Brasil, v. 53, p. 235–251, 2019. [21](#)
- PAVLOPOULOS, J.; ANDROUTSOPOULOS, I. Aspect term extraction for sentiment analysis: New datasets, new evaluation measures and an improved unsupervised method. In: *Proceedings of the 5th Workshop on Language Analysis for Social Media (LASM)*. [S.l.: s.n.], 2014. p. 44–52. [17](#)
- PENG, L.; CUI, G.; ZHUANG, M.; LI, C. What do seller manipulations of online product reviews mean to consumers? 2014. [15](#), [20](#)
- PEREIRA, C. M.; MARINHO, R. S.; SEGUNDO, J. E. S. Sentiment analysis to support book selection: a study applied to the skoob platform. *Encontros Bibli*, 2022. [9](#)
- POPESCU, A.-M.; ETZIONI, O. Extracting product features and opinions from reviews. In: *Natural language processing and text mining*. [S.l.]: Springer, 2007. p. 9–28. [24](#)
- RAMTEKE, J.; SHAH, S.; GODHIA, D.; SHAIKH, A. Election result prediction using twitter sentiment analysis. In: IEEE. *2016 international conference on inventive computation technologies (ICICT)*. [S.l.], 2016. v. 1, p. 1–5. [21](#)
- RUSTAMOV, S.; MUSTAFAYEV, E.; CLEMENTS, M. A. Sentiment analysis using neuro-fuzzy and hidden markov models of text. In: IEEE. *2013 Proceedings of IEEE Southeastcon*. [S.l.], 2013. p. 1–6. [19](#)
- SANTOS, L. M.; ESMIN, A. A. A.; ZAMBALDE, A. L.; NOBRE, F. M. Twitter, análise de sentimento e desenvolvimento de produtos: Quanto os usuários estão expressando suas opiniões? *Prisma. com*, n. 13, p. 159–170, 2010. [20](#)
- SARAWAGI, S. *Information extraction*. [S.l.]: Now Publishers Inc, 2008. [13](#)
- SAUSEN, F. J. *Projeto e desenvolvimento de um sistema para definição de aspectos e análise de sentimentos em textos*. Dissertação (B.S. thesis), 2016. [14](#), [23](#)
- SEBASTIANI, F. Machine learning in automated text categorization. *ACM computing surveys (CSUR)*, ACM New York, NY, USA, v. 34, n. 1, p. 1–47, 2002. [27](#)
- SHAH, D.; ISAH, H.; ZULKERNINE, F. Stock market analysis: A review and taxonomy of prediction techniques. *International Journal of Financial Studies*, Multidisciplinary Digital Publishing Institute, v. 7, n. 2, p. 26, 2019. [21](#)
- SILVA, F. R. P. d. *TScoop-avaliação de ferramentas para análise de sentimento: um estudo de caso no twitter*. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2019. [23](#)
- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information processing & management*, Elsevier, v. 45, n. 4, p. 427–437, 2009. [27](#)
- TAUSCZIK, Y. R.; PENNEBAKER, J. W. The psychological meaning of words: Liwc and computerized text analysis methods. *Journal of language and social psychology*, Sage Publications Sage CA: Los Angeles, CA, v. 29, n. 1, p. 24–54, 2010. [22](#)

- TECH, D. Aprendizado supervisionado ou não supervisionado. *Disponível: <https://didatica.tech/aprendizado-supervisionado-ou-nao-supervisionado/>*, Acesso: Março, 2022. 15
- THET, T. T.; NA, J.-C.; KHOO, C. S. Aspect-based sentiment analysis of movie reviews on discussion boards. *Journal of information science*, Sage Publications Sage UK: London, England, v. 36, n. 6, p. 823–848, 2010. 16
- TRIPATHY, A. R.; MOHARANA, A. K.; TRIPATHY, A.; SAHOO, S. Sentiment analysis of twitter tweet using machine learning. In: *Electronic Systems and Intelligent Computing*. [S.l.]: Springer, 2022. p. 423–431. 9
- TSYTSARAU M; PALPANAS, T. Survey on mining subjective data on the web. *Data Min Knowl Disc* 24, p. 478–514, 2012. 11, 12, 13
- TUMASJAN, A.; SPRENGER, T.; SANDNER, P.; WELPE, I. Predicting elections with twitter: What 140 characters reveal about political sentiment. In: *Proceedings of the International AAAI Conference on Web and Social Media*. [S.l.: s.n.], 2010. v. 4, n. 1, p. 178–185. 21
- YU, Y.; DUAN, W.; CAO, Q. The impact of social and conventional media on firm equity value: A sentiment analysis approach. *Decision support systems*, Elsevier, v. 55, n. 4, p. 919–926, 2013. 11, 15